www.unal.edu.co/icn/publicaciones/caldasia.htm Caldasia 28(1):45-56. 2006

BIOINDICACIÓN DE LA CALIDAD DEL AGUA EN LA SABANA DE BOGOTA – COLOMBIA, MEDIANTE LA UTILIZACIÓN DE LA LÓGICA DIFUSA NEURO-ADAPTATIVA COMO HERRAMIENTA

Bioindication of water quality at the sabanna of Bogota-Colombia, using neuro-adaptative fuzzy logic

JUAN DAVID GUTIÉRREZ
Dept. Biología - Universidad Nacional de Colombia-Bogotá. jdgutierrezt@unal.edu.co

WOLFGANG RISS
Abt. Limnologie - Universität Münster Alemania. riss@uni-muenster.de

RODULFO OSPINA
Dept. Biología - Universidad Nacional de Colombia-Bogotá. rospinat@unal.edu.co

RESUMEN

Se presenta una implementación de la metodología de Lógica Difusa Neuro-Adaptativa (LDN-A) que permite una estimación cuantitativa de la calidad del agua en la Sabana de Bogotá, Colombia. Se emplearon un total de 55 sitios correspondientes a 11 subcuencas de la Sabana de Bogotá. Los resultados obtenidos con la aplicación de la LDN-A fueron confrontados con los valores del índice fisicoquímico Cfq, para comprobar el nivel de confiabilidad de la metodología de LDN-A, observándose una regresión significativa.

Palabras clave. Lógica Difusa Neuro-Adaptativa, macroinvertebrados acuáticos, calidad del agua, Sabana de Bogotá.

ABSTRACT

An application of Neuro-Adaptative Fuzzy Logic (LDN-A) for calculating of the water quality at the Plain of Bogotá, Colombia is presented. Fifty five sites in eleven watersheds in the Plain of Bogotá are used. The results with LDN-A are confronted with values of the Cfq index, to prove the degree of reliability, a significant regression being observed.

Key words. Neuro-Adaptative Fuzzy Logic, aquatic macroinvertebrates, water quality, Savanna of Bogotá.

INTRODUCCIÓN

El monitoreo de la calidad del agua de un río por medio del muestreo de macroinvertebrados, requiere la interpretación de datos biológicos en relación con las variaciones físicas y químicas (Cairns et al. 1993). Los monitoreos biológicos son frecuentemente usados por las autoridades ambientales, para hacer juzgamientos sobre la calidad del agua, debido a la necesidad de conservar y manejar el recurso hídrico.

Los métodos de evaluación de la calidad del agua con macroinvertebrados acuáticos ofrecen ventajas tales como: simplicidad metodológica, rapidez de los resultados y una alta confiabilidad de los mismos (Reice

& Wohlenberg 1992), lo que hace de estos métodos una herramienta idónea para la vigilancia rutinaria de las cuencas y ríos en general (Winner et al. 1980).

Idealmente, los datos biológicos deberían proveer rigurosos estándares para la calidad del agua, basados en el entendimiento de sus relaciones con el ambiente acuático (Wiederholm 1984). Sin embargo, el gran número de interacciones resultantes entre las variables físicas, químicas y los organismos, se constituye en un problema matemático de gran complejidad, por lo que se requiere de técnicas sofisticadas para el análisis multivariado de modelos no lineales. La LDN-A ofrece una posibilidad debido a su fácil comprensión, pues es una extensión del sentido común para la solución de problemas matemáticos complejos, la habilidad para reconocer patrones y su capacidad de hacer inferencias sobre nuevos datos.

Esta técnica, al igual que la lógica difusa, posee la habilidad de procesar simultáneamente la información "subjetiva" proveniente de expertos y la información "objetiva" recopilada mediante datos. Dicha habilidad resulta interesante si se reconoce que la asignación de los valores de indicación para los organismos en un sistema de bioindicación es una labor subjetiva, que depende del conocimiento de la taxonomía de los diferentes grupos de organismos acuáticos, la biogeografía de los mismos y su autoecología.

En Europa y los Estados Unidos, la asignación de los organismos y de los valores de indicación para los macroinvertebrados acuáticos, ha sido obtenida a partir del conocimiento subjetivo de los investigadores individuales, formalizado en la mayoría de los casos mediante un "consenso de expertos", pero que es soportado al menos parcialmente, por el conocimiento de la fauna, así como de la información física y química de los ríos de estas regiones.

En este artículo se pretende poner a consideración los resultados obtenidos con la implementación de un sistema de LDN-A, como herramienta para la estimación de la calidad fisicoquímica del agua, empleando un pequeño grupo de taxones de macroinvertebrados como bioindicadores.

Lógica Difusa Neuro-Adaptativa

La Lógica Difusa Neuro-Adaptativa es una técnica de modelamiento matemático, que combina las ventajas de la lógica difusa y las redes neuronales (Kapur & Mundy 1988, Jang & Sun 1997). Comúnmente es clasificada como una técnica de inteligencia artificial (Dubois & Prade 1980) y es una herramienta emparentada con la lógica multivaluada (Boyer 1979, Zadeh 1988) y los métodos de inferencia con conjuntos difusos (Kaufmann & Gupta 1985). En general, se trata de una teoría que relaciona los objetos con límites no definidos en los cuales la pertenencia a un conjunto es abordada desde la perspectiva de diferentes grados de certeza (Anderson 1983), ajustados mediante técnicas de redes neuronales.

Por ejemplo, el enunciado "El vaso está lleno", en lógica binaria tendría el valor de verdadero (1) si el recipiente contiene tanto líquido como su capacidad máxima lo permite; por el contrario, si el vaso contiene el 90% de su capacidad total, el enunciado sería falso (0). En tal caso, aunque falso, parece evidente que es casi verdadero, puesto que casi está lleno. La lógica multivaluada permite asignar diferentes grados de certeza; de esta forma si el vaso está al 90% de su capacidad, el valor de verdadero del enunciado sería 0.9 (casi verdadero), mientras que si contiene, por ejemplo, un 10% de líquido el valor sería 0.1 (poco verdadero).

Por tanto, en lógica difusa se trabaja con conjuntos que se definen por sus funciones de pertenencia, que se denotan como $\mu \boldsymbol{C} (x)$ e indican el grado de pertenencia (entre 0 y

1) del elemento con valor *x* al conjunto ***C***. En LDN-A dichas funciones de pertenencia son ajustadas mediante el modelamiento de redes neuronales.

Por ejemplo, se podrían tener dos conjuntos de tipos de peso de personas que tuvieran valores dentro de los siguientes rangos (fig. 1):

Delgado = {40,....,70 Kg} Normal = {55,....,85 Kg}

En este caso, una persona con un peso 58 Kg pertenecería en un 90% (µ Delgado(58) = 0.9) al conjunto de personas Delgadas y en 0.16% (µ Normal(58) = 0.16) a las de peso Normal. En contraposición en lógica binaria se utilizan los conjuntos no difusos o precisos, donde los grados de pertenencia son binarios (0 ó 1) como se muestra en la figura 1(b).

En lógica difusa, las operaciones entre conjuntos se plantean en forma de operaciones difusas entre sus funciones de pertenencia, las operaciones más empleadas para los conjuntos son la Unión (∪), Intersección (∩), Complemento (-), Suma lógica difusa (∨) y Producto lógico difuso (∧); además de negación difusa para las funciones de pertenencia.

Las diferencias principales de la LDN-A con respecto a la lógica difusa se fundamentan en:

1. Las funciones de pertenencia para las entradas son ajustadas mediante técnicas de redes neuronales.
2. No existen funciones de pertenencia para las respuestas, sino que dichas funciones son remplazadas por constantes.
3. Cambia y afina sus reglas a medida que se recogen nuevos datos.

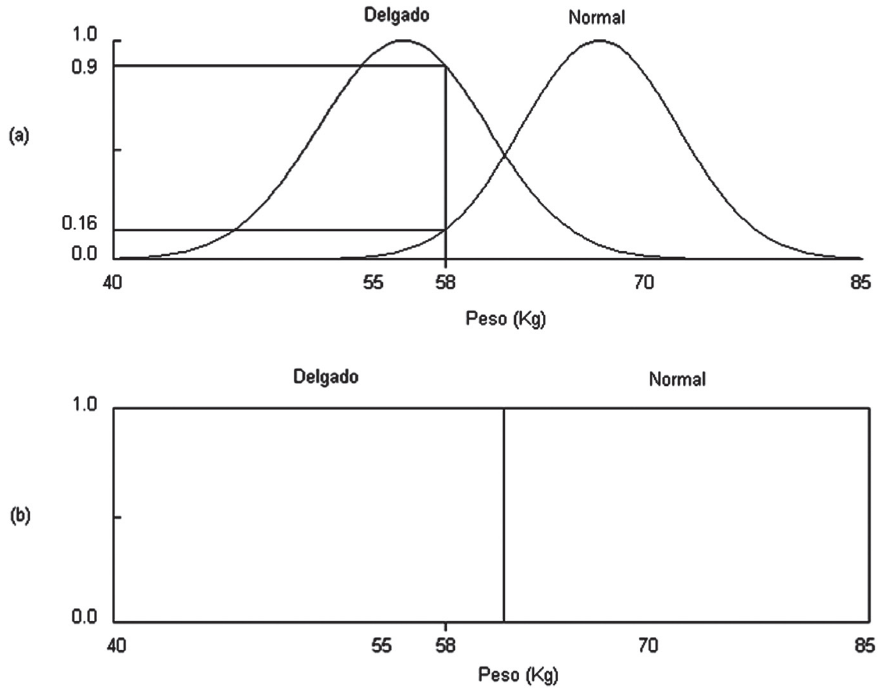

Figura 1. Ejemplos de conjuntos difusos (a) y conjuntos no difusos (b). En el caso de los conjuntos difusos, es posible aceptar diferentes matices para un enunciado, mientras que en los conjuntos no difusos solo existe un par de posibilidades mutuamente excluyentes.

Para entender la mecánica del proceso de inferencia, las reglas de decisión y agregación supóngase el siguiente ejemplo:

Se desea obtener un modelo para evaluar el volumen de ventas (variable respuesta) de un libro mediante los criterios de CONTENIDO y PRESENTACIÓN; ambos criterios son evaluados en un rango de 0 a 100 siendo 100 el mejor. La variable lingüística CONTENIDO esta compuesta por tres funciones de pertenencia: *pobre*, *aceptable* y *bueno*, mientras que la variable PRESENTACION posee dos funciones de pertenencia: *simple* y *atractiva*. La función de respuesta es TIPO DE LIBRO en un rango de 0 a 100 y posee tres constantes tres valores difusos: *malo*, *promedio* y *excelente*.

Las reglas de decisión planteadas para este ejemplo son:

1. SI CONTENIDO es *pobre* Y PRESENTACION es *simple* ENTONCES libro es *malo*
2. SI CONTENIDO es *aceptable* ENTONCES libro es *promedio*
3. SI CONTENIDO es *bueno* Y PRESENTACION es *atractiva* ENTONCES libro es *excelente*

Supóngase que la forma inicial de todas las funciones de pertenencia de las variables de entrada (CONTENIDO Y PRESENTACIÓN) es triangular. Después del proceso de aprendizaje de la red neuronal con base en la variable respuesta (TIPO DE LIBRO), dichas funciones de pertenencia son ajustadas con el objetivo de incrementar la precisión del modelo (fig. 2).

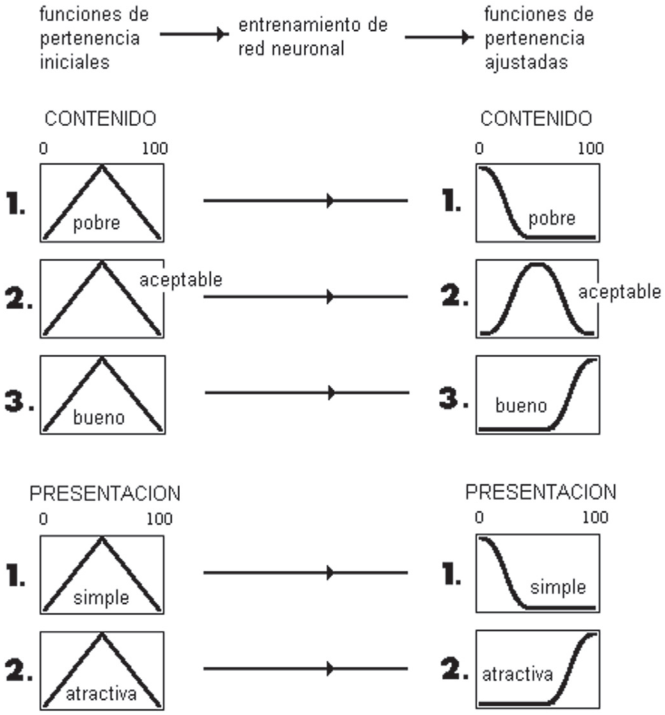
funciones de pertenencia iniciales
entrenamiento de red neuronal
funciones de pertenencia ajustadas
CONTENIDO
0
100
1.
pobre
2.
aceptable
3.
bueno
CONTENIDO
0
100
1.
pobre
2.
aceptable
3.
bueno
PRESENTACION
0
100
1.
simple
2.
atractiva
PRESENTACION
0
100
1.
simple
2.
atractiva

Figura 2. Ejemplo del ajuste de las funciones de pertenencia, por efecto del entrenamiento de la red neuronal incorporada en el sistema de LDN-A. Inicialmente todas las funciones de pertenencia son funciones triangulares simétricas con un valor máximo en la mitad. Después del aprendizaje de la red neuronal, se produce un ajuste en cada función de pertenencia, dicho ajuste reconfigura cada función de pertenencia, de acuerdo al grado de aprendizaje de la red neuronal.

Una vez ajustadas las funciones de pertenencia se procede al análisis de las reglas de decisión de la lógica difusa. La figura 3, muestra como se evalúa una sola regla de decisión. Obsérvese como la regla está dividida en un antecedente y un consecuente. Las entradas para el proceso de implicación son las entradas en el antecedente, debe resaltarse la forma como el consecuente es redibujado usando sólo una función asociada con el valor de la entrada en el antecedente (CONTENIDO = pobre) debido a que es la única con una respuesta mayor que 0 .

La figura 4, muestra la forma como la lógica difusa integra las reglas de decisión y se realiza la agregación de las respuestas. Este tipo de diagramas se conoce como diagramas de inferencia (Zadeh 1965). Nótese que el flujo de información se inicia en las entradas, luego cruza cada una de las tres reglas de decisión y las constantes en la salida (*malo*, *promedio* y *excelente*), para finalmente integrarse en un único diagrama donde se realiza la defuzificación por el método del promedio ponderado. Mayores detalles sobre la técnica de Lógica Difusa Neuro-Adaptativa pueden encontrarse en: Hunt (1975), Jang (1991), Gupta & Rao (1994) y Jang & Gulley (1994).

Datos

Con el objeto de abarcar un amplio espectro de ríos con diferentes estados de intervención en la cuenca alta y media del río Bogotá, se emplearon los datos reportados por Bohórquez (1989), Soler & Mora (1993), Bohórquez & Ardila (1997), Riss et al. (2002), Leyton (2003) y los datos sin publicar suministrados por el Laboratorio de Aguas de la Empresa de Acueducto y Alcantarillado de Bogotá (LAEAAB). En total se seleccionaron 55 sitios; con esta información se construyó una base de datos, en la que cada sitio tiene un registro de las variables físicas y químicas muestreadas y de los macroinvertebrados encontrados. Las variables físicas y químicas empleadas en el análisis fueron 21, mientras que el número de taxones incluidos fue de 62.

Para la estimación de la calidad del agua se empleó el índice de calidad fisicoquímica Cfq (Riss et al. 2002), debido que a diferencia de otros índices, este permite calcular un valor de calidad fisicoquímica del agua, con cualquier número de variables físicas y químicas, con lo que es posible comparar diferentes sitios en los que no todas las variables físicas y químicas han sido monitoreadas. Los valores

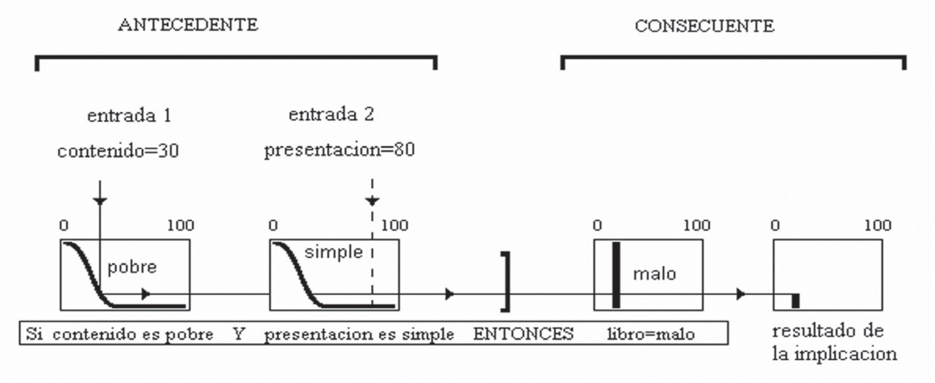

Figura 3. Ejemplo del resultado obtenido por de la implicación de una regla de decisión. Las entradas al sistema constituyen el antecedente y la salida el consecuente. La función de pertenencia en el consecuente es redibujada, usando en este caso, solo un valor de la entrada en el antecedente (contenido = pobre) debido a que es el único con una respuesta mayor que 0 .

del índice Cfq fueron transformados a una escala de 0 a 100, al multiplicar el valor del índice por 10, de tal forma que 100 corresponde a aguas extremadamente limpias y 0 corresponde a aguas extremadamente sucias. Para los sitios analizados en éste análisis los valores del índice Cfq variaron entre 94.1 y 8.7, lo que permite abarcar un amplio rango de valores de calidad del agua y facilita el reconocimiento de patrones por parte de la red neuronal (Kasabov 1996, Horikawa et al. 1992, Jang 1993).

Implementación de la Lógica Difusa Neuro-Adaptativa

Para la implementación de la LDN-A fue necesario el desarrollo de un programa de computador llamado ADFUZZY escrito en Matlab.

Previo a la aplicación de la LDN-A, se seleccionaron los organismos indicadores. El principal criterio empleado para la selección de dichos organismos fue la condición de estenóico de cada uno de ellos para las

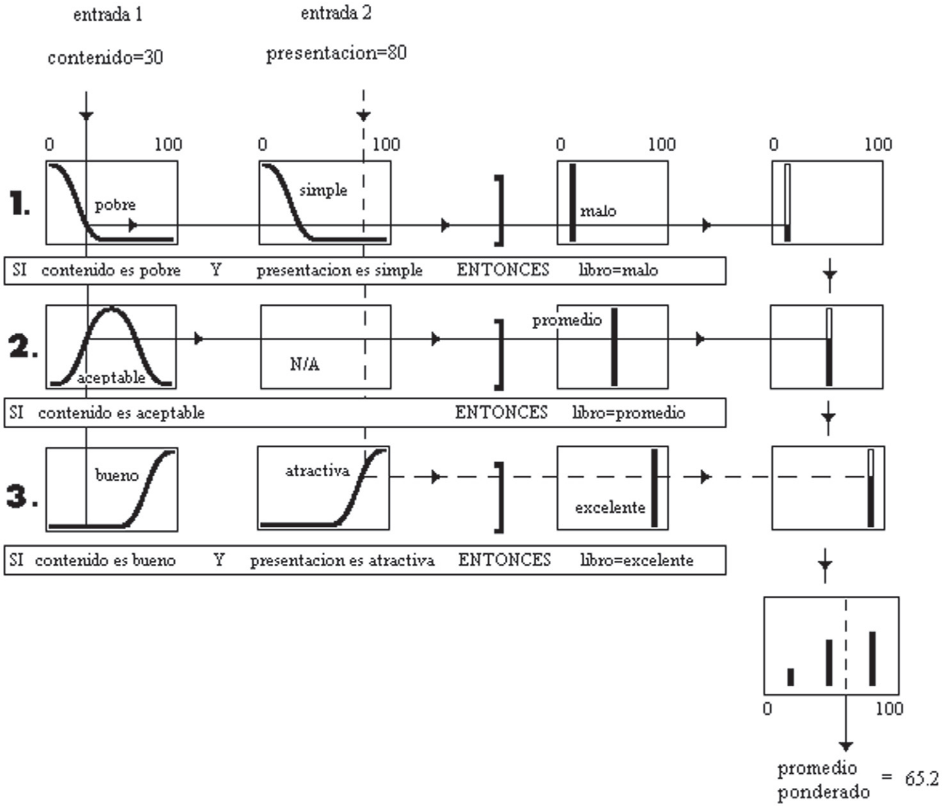
entrada 1
contenido=30
entrada 2
presentacion=80
0
100
0
100
0
100
0
100
1.
pobre
simple
malo
SI contenido es pobre Y presentacion es simple ENTONCES libro=malo
2.
aceptable
N/A
promedio
SI contenido es aceptable ENTONCES libro=promedio
3.
bueno
atractiva
excelente
SI contenido es bueno Y presentacion es atractiva ENTONCES libro=excelente
0
100
promedio ponderado = 65.2

Figura 4. Ejemplo de un diagrama de inferencia. El flujo de información se inicia en las entradas, a partir de allí cruza cada una de las reglas de decisión y las funciones de pertenencia en la salida (malo, promedio y excelente). Por ultimo, la información se integra en un único diagrama en la esquina inferior derecha donde se realiza la desdifusificación por el método del promedio ponderado (N/A= No Aplica).

distintas condiciones de calidad de agua. De tal forma que la información para dicha selección esta asociada con la distribución y abundancia de cada uno de los organismos a lo largo del espectro de calidad del agua.

Los organismos seleccionados por su condición estenóica para la implementación del modelo de LDN-A fueron: Leptoceridae (1) e Hidrobiosidae (2) como indicadores de aguas limpias, Planariidae (3) y Amphipoda (4) como indicadores aguas contaminadas y como indicadores de aguas muy contaminadas se seleccionaron: Oligochaeta (5), Psychodidae (6) y Syrphidae (7).

La función de pertenencia inicial para los bioindicadores fue en todos los casos una función gausiana.

Para el entrenamiento de la red neuronal se emplearon los valores del índice Cfq de los 55 sitios y las funciones iniciales de pertenencia. El algoritmo empleado por la red para el aprendizaje fue un método híbrido que incluía los métodos de mínimos cuadrados y retropropagación.

Las reglas de decisión del sistema de LDN-A tienen un enunciado de la forma: SI (organismo *x*) → ENTONCES (calidad del agua = *y*), para indicar la acción a realizar de acuerdo al conjunto al que pertenece el organismo suministrado en el vector de entrada. Para definir qué regla (o reglas) se activa ante una determinada entrada (organismo), se parte del grado de pertenencia de dicho organismo a cada uno de los diferentes conjuntos difusos.

Para la construcción de las reglas de decisión se emplearon las combinaciones de organismos indicadores que fueron observadas en siete clases a priori de calidad del agua (extremadamente buena, muy buena, buena, regular, mala, muy mala y extremadamente mala) y las cuales constituyen igualmente las constantes de la respuesta, en este caso los valores de las constantes fueron:

Extremadamente buena = 100
Muy buena = 85
Buena = 70
Regular = 50
Mala = 30
Muy mala = 15
Extremadamente mala = 0

De ésta forma el rango de la respuesta del sistema de LDN-A se encuentra entre 0 y 100.

Por ejemplo, la regla:

SI Amphipoda Y Planariidae ENTONCES calidad del agua = regular

Describe que la presencia simultánea de los taxa Amphipoda y Planariidae, produce una respuesta en la que la calidad del agua es regular. Pero como se mencionó anteriormente, el valor de la respuesta (calidad del agua) depende del grado de pertenencia a los conjuntos difusos correspondientes que se incluya en el vector de entrada (abundancia de los taxa Amphipoda y Planariidae).

Las nueve reglas de decisión empleadas fueron:

1. SI Leptoceridae Y Hidrobiosidae ENTONCES calidad del agua = muy buena
2. SI Planariidae O Amphipoda ENTONCES calidad del agua = regular
3. SI Leptoceridae O Hidrobiosidae ENTONCES calidad del agua = muy buena
4. SI Planariidae Y Amphipoda ENTONCES calidad del agua = regular
5. SI Psychodidae Y Syrphidae ENTONCES calidad del agua = muy mala

6. SI Leptoceridae Y Hidrobiosidae Y Planariidae ENTONCES calidad del agua = buena
7. SI Oligochaeta Y Psychodidae Y Syrphidae ENTONCES calidad del agua = mala
8. SI Leptoceridae Y Hidrobiosidae Y Amphipoda ENTONCES calidad del agua = buena
9. SI Psychodidae O Syrphidae ENTONCES calidad del agua = muy mala

La defuzificación de las salidas consistió en obtener un valor numérico para la calidad del agua a partir de los conjuntos difusos a los que pertenecen los organismos del vector de entrada. Para este caso se empleó como método de defuzificación el método del promedio ponderado.

La figura 5 muestra la arquitectura del modelo de LDN-A, en cada una de las capas se enumera el número del nodo. En el caso de las entradas el número corresponde al indicador y en el caso de las reglas corresponde al enunciado de la regla. Adicionalmente se ha incorporado un nodo en la capa de la salida individual de las reglas, el cual corresponde a un factor de normalización (N), empleado durante el proceso de aprendizaje de la red neuronal.

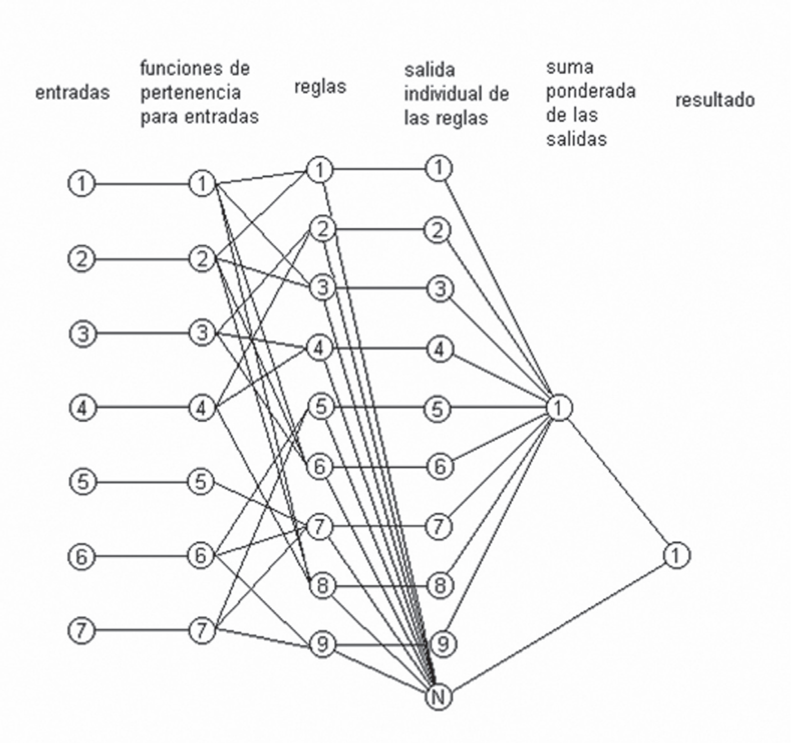
entradas
funciones de pertenencia para entradas
reglas
salida individual de las reglas
suma ponderada de las salidas
resultado
1
2
3
4
5
6
7
8
9
N

Figura 5. Arquitectura del modelo de LDN-A implementado. Cada neurona de la capa de entrada corresponde a uno de los organismos empleados como indicadores, a cada neurona de ésta capa corresponde una neurona en la capa funciones de pertenencia. La capa de las reglas de inferencia incluye nueve neuronas, una para cada regla, el resultado de cada regla es pasado a la capa de salidas individuales, la cual incluye un factor de normalización (N). Por ultimo las salidas se ponderan en una neurona de salidas ponderadas, que posteriormente se normaliza para el resultado final suministrado por una neurona en la capa de resultado.

Evaluación del desempeño

Como se mencionó anteriormente, para comparar los resultados suministrados por el modelo de LDN-A, se empleó el valor del índice fisicoquímico Cfq para las mismas 55 estaciones.

Las abundancias de los grupos indicadores fueron transformadas para ser expresadas en una escala de 0 a 1 (con 1 = 100 o mas individuos), con excepción de los oligoquetos que fueron expresados en una escala de 0 a 10 (con 10 = 1000 o mas individuos), debido a su gran abundancia. De esta forma los 55 vectores de entrada (1 para cada estación) al sistema, tenían una dimensión de 1 X 7 (1 valor de abundancia para los 7 taxones).

Una vez construido y ajustado el modelo de LDN-A, se calcularon los valores de calidad del agua para las estaciones de muestreo. La figura 6 muestra la diferencia entre los valores calculados por el modelo y los valores del índice fisicoquímico Cfq. Adicionalmente se calculó la regresión lineal entre los resultados del modelo de LDN-A y los valores del índice Cfq; dicha regresión es significativa ($R^2=0.96$, $p<0.05$, $n=55$).

Conclusión

La aplicación de la LDN-A como herramienta de análisis de la calidad del agua con base en macroinvertebrados acuáticos, ofrece las mismas ventajas de la bioindicación, tales como: simplicidad metodológica y rapidez de los resultados, pero adicionalmente proporciona una considerable disminución del tiempo dedicado a las determinaciones taxonómicas (7 taxones), lo cual puede ser crítico cuando la disponibilidad de tiempo y recursos lo requiera.

Además el modelamiento con LDN-A proporciona una alta confiabilidad de los resultados, debido a la capacidad de esta técnica de combinar la simplicidad conceptual de la lógica difusa y el poder predictivo de las redes neuronales, ofreciendo soluciones aceptables a problemas matemáticos complejos, como los asociados a la calidad del agua y sus interacciones con la fauna acuática.

La flexibilidad de la metodología propuesta permite implementarla en diferentes áreas de interés, con la simple adopción de los ajustes correspondientes tales como: organismos indicadores y reglas de decisión.

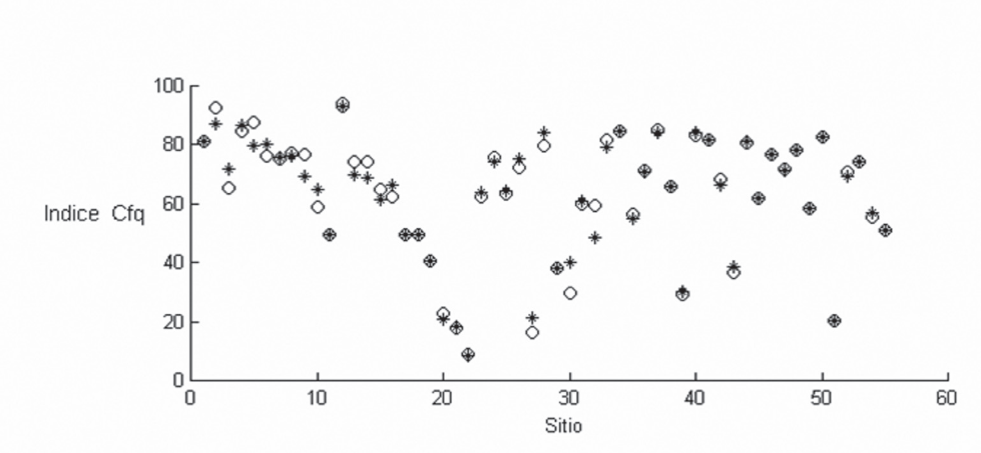

Figura 6. Variación entre el índice de calidad física y química Cfq (°) y los valores de bioindicación obtenidos con LDN-A (*). En el caso que las estimaciones con el sistema de LDN-A, fueran absolutamente exactas, ambos símbolos se deberían superponer.

Agradecimientos

Este trabajo es parte de los resultados del Proyecto "Quironómidos de la Sabana", financiado por Colciencias. (Contrato 065/96 Colciencias - Universidad Nacional). El primer autor agradece a Colciencias por la asignación de una beca para estudios de doctorado, igualmente todos los autores agradecen a esta misma entidad el efectivo apoyo técnico y financiero. Al Servicio Alemán de Intercambio Académico (DAAD) por el apoyo al primer autor mediante una beca de investigación. A la Fundación Alexander von Humbold (AvH) por el apoyo al tercer autor mediante una beca de investigación, a la agencia alemana GTZ por la donación de equipos y apoyo general al proyecto, a la Facultad de Ciencias y al Departamento de Biología de la Universidad Nacional de Colombia por la construcción y dotación de laboratorios y apoyo al proyecto. A los demás miembros del equipo de trabajo por su ayuda en la identificación de la fauna bentónica.

Literatura citada

ANDERSON, J. R. 1983. The architecture of congnition. Cognitive sciences series. Harvard University Press. Cambridge, MA.

BOHORQUEZ, A. 1989. Contribución al estudio limnológico por bioindicadores con macroinvertebrados bentónicos en aguas continentales. Proyecto Limnología Unincca - Colciencias. IP 1227-09004-89. Bogotá.

BOHORQUEZ, A., J. L. ARDILA. 1997. Monitoreo limnológico con macroinvertebrados en cuatro estaciones localizadas en los ríos Barandillas y Frio. Unisalle Dep. Quim. Biol. Diógenes 4(1): 37-59.

BOYER, R. S. 1979. A computational logic. Academic Press. New York.

CAIRNS, J., P. V. MCCORMICK, B. R. NIEDERLEHNER 1993. A proposed framework for developing indicators of ecosystem health. Hydrobiologia 263: 1-44.

DUBOIS, D. & H. PRADE. 1980. Fuzzy Sets and Systems: Theory and Applications. Academic Press. New York.

GUPTA, M. & D. H. RAO. 1994. On the Principles of Fuzzy Neural Networks. Fuzzy Sets and Systems 61(1): 1-18.

HORIKAWA, S., T. FURUHASHI, Y. UCHIKASA. 1992. On Fuzzy Modelling Using Fuzzy Neural Networks with Back-Propagation Algorithm. IEEE Transactions on Neural Networks 3(5): 801-806.

HUNT, E. B. 1975. Artificial Intelligence. Academic Press. New York.

JANG, J.-S. R. 1991. Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm. Proc. of the Ninth National Conf. on ArtificialIntelligence (AAAI-91): 762-767.

JANG, J.-S. R. 1993. ANFIS: Adaptive-Network-based Fuzzy Inference Systems. IEEE Transactions on Systems, Man, and Cybernetics 23(3): 665-685.

JANG, J.-S. R. & C.-T. SUN. 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice Hall. New York.

JANG, J.-S. R. & N. GULLEY. 1994. Gain scheduling based fuzzy controller design. Proc. of the International Joint Conference of the North American Fuzzy Information Processing Society Biannual Conference. The Industrial Fuzzy Control and Intelligent Systems Conference and the NASA Joint Technology Workshop on Neural Networks and Fuzzy Logic. San Antonio, Texas.

KAPUR, D & J. L. MUNDY. 1988. Geometric reasoning. En: Kapur, D & J. L. Mundy (Editores). MIT Press. Cambridge, MA.

KASABOV, N. 1996. Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering. MIT Press. Cambridge, MA.

KAUFMANN, A. & M. M. GUPTA. 1985. Introduction to Fuzzy Arithmetic. V. N. Reinhold.

LEYTON, M. 2003. Caracterización de macroinvertebrados acuáticos en algunas quebradas orientales de Bogotá.

Tesis (Biólogo) Universidad Nacional de Colombia. Facultad de ciencias. Departamento de Biología.

Reice, S. R. & M. Wohlenberg. 1992. Monitoring Freshwater Benthic Macroinvertebrates and Benthic Processes: Measures for Assessment of Ecosystem Health. En: D. M. Rosenberg and V. H. Resh (editores). Freshwater Biomonitoring and Benthic Macroinvertebrates. pp 287:305. Chapman & Hall. NewYork.

Riss, W., R. Ospina, J. D. Gutierrez. 2002. Establecimiento de valores de bioindicación para los macroinvertebrados acuáticos de la Sabana de Bogotá. Caldasia 24 (1): 135-156.

Soler, M. X., A. Y. Mora. 1993. Estudio limnológico con énfasis en los macroinvertebrados bénticos de la parte alta del río Bogotá (Quebrada del valle, planta de tratamiento de Tibito). Tesis (Biólogo) Universidad Nacional de Colombia. Facultad de ciencias. Departamento de Biología.

Wiederholm, T. 1984. Responses of aquatic insects to environmental pollution. En: V. H. Resh and D. M. Rosenberg. (editores). The ecology of aquatic insects. pp 508:557. Praeger Pubs. NewYork.

Winner, R. W., M. W. Boesel, M. P. Farrell. 1980. Insect community structure as an index of heavy-metal pollution in lotic ecosystems. Can. Jou. Fish. Aqu. Sci. 37: 647-655.

Zadeh, L. A. 1965. Fuzzy sets. Information and Control. 8: 338-353.

Zadeh, L. A. 1988. Fuzzy Logic. Computer 1(4): 83-93.

Recibido: 07/02/2006
Aceptado: 00/00/2006